

최적화된 pRBF 뉴럴 네트워크에 의한 정적 상황 인지 시스템에 관한 연구

논 문
60-12-28

A Study on Static Situation Awareness System with the Aid of Optimized Polynomial Radial Basis Function Neural Networks

오 성 권[†] · 나 현 석^{*} · 김 옥 동^{**}
(Sung-Kwun Oh · Hyun-Suk Na · Wook-Dong Kim)

Abstract - In this paper, we introduce a comprehensive design methodology of Radial Basis Function Neural Networks (RBFNN) that is based on mechanism of clustering and optimization algorithm. We can divide some clusters based on similarity of input dataset by using clustering algorithm. As a result, the number of clusters is equal to the number of nodes in the hidden layer. Moreover, the centers of each cluster are used into the centers of each receptive field in the hidden layer. In this study, we have applied Fuzzy-C Means(FCM) and K-Means(KM) clustering algorithm, respectively and compared between them. The weight connections of model are expanded into the type of polynomial functions such as linear and quadratic. In this reason, the output of model consists of relation between input and output. In order to get the optimal structure and better performance, Particle Swarm Optimization(PSO) is used. We can obtain optimized parameters such as both the number of clusters and the polynomial order of weights connection through structural optimization as well as the widths of receptive fields through parametric optimization. To evaluate the performance of proposed model, NXT equipment offered by National Instrument(NI) is exploited. The situation awareness system-related intelligent model was built up by the experimental dataset of distance information measured between object and diverse sensor such as sound sensor, light sensor, and ultrasonic sensor of NXT equipment.

Key Words : Radial basis function neural network, Fuzzy C means clustering, K-means clustering, Particle swarm optimization, NXT, Situation awareness.

1. 서 론

지능형 시스템의 점진적인 성장은 다양한 과학 및 공학 분야에서 주목을 받고 있다. 그 중 방사형 기저 함수 신경회로망(Radial Basis Function Neural Networks; RBFNNs)은 기존의 다중(multilayer) 신경 회로망보다 구조가 간단하고 학습능력이 빠른 특징을 갖고 있으며 퍼지 모델에 비해 비선형적이고 다변수인 시스템을 대상으로 한 모델링에서 우수한 성능을 보인다. 따라서 function approximation, regularization, noisy interpolation, 패턴인식[3]과 같은 다양한 응용분야에서 연구되고 있다[1].

현재 컴퓨터 지능 분야에서는 두 개 이상의 모델을 합성한 퍼지 신경 회로망[2,6], 퍼지 다항식 신경 회로망[3,5]과 같은 다양한 형태의 모델이 제안되고 있으며, 주어진 입력과 출력데이터를 분석하고 유사성을 판단하기 위해 클러스터링 기술을 결합한 모델이 연구되고 있다. 클러스터링 방법으로는 FCM (Fuzzy C-Means) [7], K-Means [8], Mountain [9], Subtractive [10] 등이 대표적으로 퍼지 모델 및 신경회

로망에 적용되고 있다. 또한 모델의 전체적인 구조 및 모델을 구성하는데 필요한 파라미터들을 최적화시키기 위해 많은 연구가 이루어지고 있으며 유전자 알고리즘(GA: Genetic Algorithms)[11]과 입자군집 최적화 알고리즘(PSO: Particle Swarm Optimization)[12] 그리고 두 알고리즘의 개선된 방법들이 모델을 최적화하는데 주로 사용되고 있다. 최근에는 유전자 알고리즘(GA)의 개선된 형태로써 Differential Evolution(DE)[14]가 큰 주목을 받고 있으며, 그 외에도 Ant Colony Optimization(ACO)[13]와 Artificial Bee Colony(ABC)[14]와 같은 개미나 벌의 집단생활 양식을 바탕으로 한 최적화 알고리즘이 연구 및 적용되고 있다.

본 논문에서는 입자 군집 최적화 (Particle Swarm Optimization; PSO)로 최적화된 클러스터링 기반 방사형 기저 함수 신경회로망을 설계하는 동시에 실제 상황 인지 시스템을 구현한다. 실험 데이터 취득을 위해 NXT 장비를 사용하여 각각의 서로 다른 거리에 위치한 사물에 대해 NXT의 센서를 통해 데이터를 취득한다. 수집된 데이터를 바탕으로 제안된 모델로 시뮬레이션을 통해 데이터의 실제 거리 출력과 모델 출력을 비교하여 성능을 평가한다.

제안된 모델은 기존의 방사형 기저 함수 신경회로망의 구조로 이루어져있다. 그러나 기존의 모델과의 차이점은 다음과 같이 크게 세 가지로 나눌 수 있다.

첫째, 은닉층 활성화함수의 중심점 및 분포상수를 정의하는데 있어 클러스터링 알고리즘을 사용하였다. 본 연구에서는

† 교신저자, 시니어회원 : 수원대 공대 전기공학과 교수
E-mail : ohsk@suwon.ac.kr

* 준 회원 : 수원대 공대 전기공학과 석사과정

** 정 회원 : 수원대 공대 전기공학과 박사과정

접수일자 : 2011년 9월 19일

최종완료 : 2011년 10월 25일

FCM과 K-Means 클러스터링 알고리즘을 사용하여 각각의 모델을 설계하였다. 두 모델의 성능을 비교하여 좀 더 상환 인지 시스템에 적합한 모델을 구현하고자 하였다. K-Means 클러스터링의 경우는 입력 데이터를 은닉층의 노드 수만큼 클러스터를 구성하여 각 클러스터의 중심점을 활성화함수의 중심점으로 사용하였다. 또한 활성화함수의 분포상수는 주어진 입력 데이터와 클러스터 중심점간의 표준편차를 적용하였다. FCM 클러스터링의 경우 은닉층 자체가 FCM 알고리즘으로 대체되며 소속행렬의 소속값을 바로 은닉층의 적합도로 사용하였다.

둘째, 연결가중치를 다항식으로 구성하였다. 기존의 방사형 기저 함수 신경회로망은 단일 상수항을 사용하여 출력을 표현하였지만, 제안된 모델의 연결가중치는 상수항이외에 1차 선형식 및 2차식으로 이루어진 다항식을 연결가중치로 사용하였다. 모델의 최종출력은 입력-출력간의 관계식으로 이루어져 좀 더 정확하고 안정적인 성능을 나타낸다.

2. 클러스터링 기반 방사형 기저 함수 다항식 신경회로망의 구성

본 연구에서 제안한 클러스터링 기반 다항식 방사형 기저 함수 신경회로망(Polynomial Radial Basis Function Neural Networks; pRBFNNs)의 기본 구조는 일반적인 모델과 동일하다. 하지만 일반적인 모델과의 차이점은 크게 두 가지로 구분할 수 있다.

(a) 제안된 모델은 활성화함수로 가우시안 함수를 사용하며 클러스터링 알고리즘을 이용하여 데이터의 특징을 반영한 활성화함수를 형성하는데 중점을 두었다.

- i) K-Means 클러스터링 방법을 이용하여 활성화함수의 중심점을 결정한다. 클러스터 수만큼 데이터의 유사정도를 계산하여 그룹을 형성하고 각 그룹에 중심점이 활성화함수의 중심점으로 사용된다.
- ii) Fuzzy C Means 클러스터링 방법을 이용하여 은닉층 자체를 FCM 알고리즘으로 대체하였다. 따라서 소속행렬의 소속값을 적합도로 사용하여 좀 더 간단한 구조로 모델을 구성하였다.

(b) 연결가중치를 기존의 상수항에서 확장하여 1차 선형 및 2차식으로 표현하였다. 이는 다항식에 입력변수가 고려되어 보다 안정적인 성능을 나타내는 모델의 출력을 추론할 수 있다.

2.1 조건부

방사형 기저 함수(RBF)중 가우시안(Gaussian) 함수를 활성화함수로 사용한 은닉층의 출력은 식 (1)과 같이 표현할 수 있다.

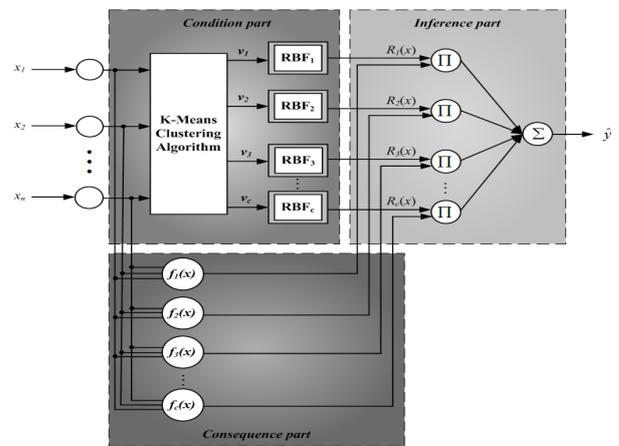
$$R_j(\mathbf{x}) = e^{-\frac{\|\mathbf{x}-\mathbf{v}_j\|^2}{2\sigma_j^2}} \quad (1)$$

여기서, x_i 는 $i(i=1, \dots, n)$ 번째 입력 데이터, v_j 은 $j(j=1, \dots, c)$ 번째 RBF의 중심점, σ 는 RBF의 활성화 영역의 분포상수를 나타낸다.

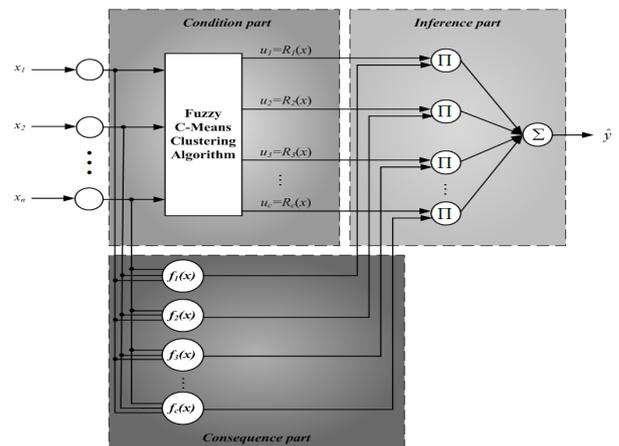
$$R_j(\mathbf{x}) = \exp\left\{-\frac{(x_1 - v_{1j})^2 + (x_2 - v_{2j})^2 + \dots + (x_n - v_{nj})^2}{2\sigma_j^2}\right\} \quad (2)$$

$$= \exp\left\{-\frac{1}{2}\left(\sum_{i=1}^n \frac{(x_i - v_{ij})^2}{\sigma_j^2}\right)\right\}$$

그림 1(a)의 경우 K-Means 클러스터링을 이용하여 식(2)의 중심점을 구한다. 또한 분포상수는 입력과 중심점의 표준편차를 적용한다. K-Means 클러스터링 알고리즘은 다음과 같다[8].



(a) K-Means clustering-based pRBFNNs



(b) Fuzzy C-Means clustering-based pRBFNNs

그림 1 클러스터링 기반 다항식 방사형 기저 함수 신경회로망의 구조

Fig. 1 Structure of clustering-based polynomial radial basis function neural networks

[단계 1] 클러스터 개수를 결정하고, 소속행렬 $U^{(0)}$ 을 0과 1로만 이루어진 값으로 초기화한다.

$$M = \left\{ U \mid u_{jk} \in 0 \text{ or } 1, \sum_{j=1}^c u_{jk} = 1, 0 < \sum_{k=1}^N u_{jk} < N \right\} \quad (3)$$

여기서, u_{jk} 은 소속행렬의 파라미터를 나타내며, c 는 클러스터의 개수를 나타내고, N 은 주어진 데이터 수를 나타낸다.

[단계 2] 소속행렬과 입력 데이터를 가지고 클러스터 개수만큼의 중심점 \mathbf{v} 를 계산한다.

$$v_{ij} = \frac{\sum_{k=1}^N u_{jk} \times x_{ki}}{\sum_{k=1}^N u_{jk}} \quad (4)$$

여기서, $j(j=1, \dots, c)$ 는 클러스터의 수를 나타내며 $i(i=1, \dots, n)$ 는 입력변수의 수를 나타내고 $k(k=1, \dots, N)$ 는 데이터의 수를 나타낸다.

[단계 3] 각 클러스터의 중심점과 데이터와의 거리를 계산하여 거리가 가까운 클러스터의 소속행렬 파라미터 u_{jk} 을 1로 바꿔주면서 새로운 소속행렬 $\mathbf{U}^{(r+1)}$ 을 생성한다.

$$d_{ij} = d(\mathbf{x} - \mathbf{v}) = \|\mathbf{x} - \mathbf{v}\| = \sqrt{\sum_{i=1}^n (x_i - v_{ij})^2} \quad (5)$$

$$u_{jk}^{(r+1)} = \begin{cases} 1 & d_{ij}^{(r)} = \min d_{ij}^{(r)} \text{ for all } j \in c \\ 0 & \text{otherwise} \end{cases} \quad (6)$$

여기서 r 은 반복횟수를 나타낸다.

[단계 4] 만일 식(7)을 만족하면 종료하고, 그렇지 않으면 $r=r+1$ 로 놓고 **[단계 2]**로 이동한다.

$$\|\mathbf{U}^{(r+1)} - \mathbf{U}^{(r)}\| \leq \epsilon \quad (7)$$

알고리즘이 종료되면 최종 \mathbf{v} 가 활성화함수의 중심점이 된다. 또한 활성화함수의 분포상수는 입력데이터와 앞서 구한 각 클러스터의 중심점간의 표준편차를 사용하며 식 (8)과 같다.

$$\sigma_{ij} = \sqrt{\frac{1}{N-1} \sum_{k=1}^N (x_i - v_{ij})^2} \quad (8)$$

그림에서 보듯이 조건부 전체가 FCM 클러스터링 알고리즘으로 그림 2(a)에 비해 구조적으로 간단하며 연산과정도 간소화되는 장점이 있다. FCM 클러스터링 알고리즘은 다음과 같다[9].

[단계 1] 클러스터의 개수 $c(2 \leq c \leq n)$ 을 정하고 퍼지화계수 $m(1 < m < \infty)$ 을 선택한다. 초기 partition matrix $\mathbf{U}^{(0)}$ 을 초기화한다. 알고리즘 반복 횟수를 $r(r=0, 1, \dots)$ 로 표시한다.

$$\mathbf{U}^{(r)} = \left\{ u_{jk} \in [0, 1], \sum_{j=1}^c u_{jk} = 1 \forall k, 0 < \sum_{k=1}^N u_{jk} < n \forall j \right\} \quad (9)$$

[단계 2] 식 (11)을 이용하여 FCM 클러스터 중심 \mathbf{v} 를 계산한다.

$$J(u_{jk}, \mathbf{v}_j) = \sum_{j=1}^c \sum_{k=1}^N u_{jk}^m (d_{jk})^2 \quad (10)$$

여기서, u_{jk} 는 0과 1사이의 소속을 나타내는 정도의 값으로 $j(j=1, \dots, c)$ 번째 클러스터에 속해져 있는 \mathbf{x}_i 의 $i(i=1, \dots, n)$ 번째 데이터의 소속정도를 나타낸다. \mathbf{v}_j 는 $j(j=1, \dots, c)$ 번째 클러스터 중심 벡터이다. m 은 partition matrix의 애매함의 정도에 대한 영향을 나타내는 퍼지화 계수이다. 이 값은 $m \in [1, \infty)$ 와 같은 범위를 가지고 있다.

식 (10)의 목적함수를 최소화하기 위해서 먼저 \mathbf{v}_j 와 u_{jk} 와 관련된 식의 목적함수를 다음과 같이 분화시켜야 한다.

$$\mathbf{v}^{(r)} = \{v_{i1}^{(r)}, \dots, v_{ic}^{(r)}\}, v_{ij}^{(r)} = \frac{\sum_{k=1}^N (u_{jk})^m \cdot x_{ki}}{\sum_{k=1}^N (u_{jk})^m} \quad (11)$$

$$u_{jk} = \frac{(1/\|\mathbf{x} - \mathbf{v}_j\|^2)^{1/m-1}}{\sum_{j=1}^c (1/\|\mathbf{x} - \mathbf{v}_j\|^2)^{1/m-1}} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{jk}}{d_{jk}}\right)^{2/m-1}} \quad (12)$$

식 (10)에서 주어진 목적함수를 만족하기 위하여 식 (12)과 식 (13)에 의해서 구해진 값들을 이용하여 각각의 클러스터 중심과 데이터와의 거리계산을 통해 새로운 소속행렬을 생성한다.

$$d_{ik} = d(\mathbf{x}_i - \mathbf{v}_j) = \left[\sum_{j=1}^c (x_{ki} - v_{ij})^2 \right]^{1/2} \quad (13)$$

[단계 3] 다음과 같이 새로운 소속행렬 $\mathbf{U}^{(r+1)}$ 을 계산한다.

$$u_{jk}^{(r+1)} = \frac{1}{\sum_{j=1}^c \left(\frac{d_{ik}^{(r)}}{d_{jk}^{(r)}}\right)^{2/(m-1)}} \quad (14)$$

[단계 4] 다음 식 (15)을 계산해서 만일 $\Delta > \epsilon$ 이면 $r=r+1$ 로 정하고 **[단계 2]**로 가서 다시 알고리즘을 반복 수행하고 그렇지 않고 $\Delta \leq \epsilon$ 이면 알고리즘을 종료한다. 여기서, ϵ 는 임계값이다.

$$\Delta = \|\mathbf{U}^{(r+1)} - \mathbf{U}^{(r)}\| = \max_{j,k} |u_{jk}^{(r+1)} - u_{jk}^{(r)}| \quad (15)$$

식(14)을 이용하여 소속행렬의 분포를 살펴보면 그림 3과 같이 방사형 형태의 활성화함수와 동일하다. 따라서 소속 값을 모델의 적합도로 사용가능하며, 퍼지화 계수(m)는 방사형 함수의 활성화 영역을 조절하는 역할을 한다. 따라서 이 값을 조절함으로써 좀 더 다양한 형태의 활성화함수를 생성할 수 있다.

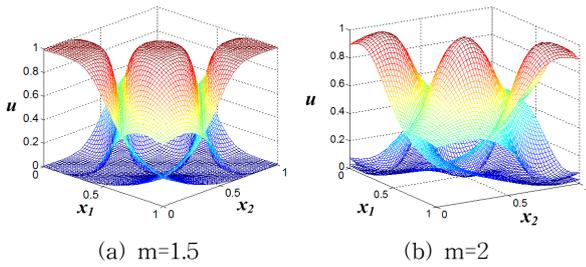


그림 2 퍼지화 계수에 따른 소속행렬의 소속값
 Fig. 2 Values of partition matrix according to fuzzification coefficient

2.2 결론부

본 연구에서는 기존에 상수항으로 표현된 연결가중치를 다항식 형태의 연결가중치로 확장하여 사용한다. 기존 상수항을 포함한 결론부의 추론형태는 네 개로 구분할 수 있으며 표1에 형태별로 나타내었다.

표 1 다항식의 서로 다른 형태.

Table 1 Different forms of the polynomial function

Type		Polynomial equation
Type 1	Constant	$f_j(\mathbf{x}) = a_{j0}$
Type 2	Linear	$f_j(\mathbf{x}) = a_{j0} + \sum_{i=1}^n a_{ji}x_i$
Type 3	Quadratic	$n = 2: f_j(\mathbf{x}) = a_{j0} + \sum_{i=1}^n a_{ji}x_i + \sum_{i=1}^n a_{j(n+i)}x_i^2 + a_{(2n+1)}x_1x_2$ $n \geq 3: f_j(\mathbf{x}) = a_{j0} + \sum_{i=1}^n a_{ji}x_i + \sum_{i=1}^n a_{j(n+i)}x_i^2 + a_{(2n+1)}x_1x_2 + \dots + a_{(n(n+1)/2)}x_{(n-1)}x_n$
Type 4	Modified Quadratic	$n = 2: f_j(\mathbf{x}) = a_{j0} + \sum_{i=1}^n a_{ji}x_i + a_{(2n+1)}x_1x_2$ $n \geq 3: f_j(\mathbf{x}) = a_{j0} + \sum_{i=1}^n a_{ji}x_i + a_{(2n+1)}x_1x_2 + \dots + a_{(n(n+3)/2)}x_{(n-1)}x_n$

여기서, type1의 constant는 기존의 상수항이며, type 2의 linear는 1차 선형식을 나타낸다. quadratic은 2차식을 나타내며, modified quadratic은 type 3에서 x_2 부분을 제외한 다항식이다. 이러한 상수항 이외에 다항식을 사용함으로써 모델의 성능을 개선시켰다.

2.3 추론부

마지막으로 추론부에서는 네트워크의 최종출력을 구하게 된다. 그림 1의 $R_j(\mathbf{x})(j=1, 2, \dots, c)$ 는 은닉층 j번째 뉴런의 출력 신호이며, 이 출력신호는 은닉층과 출력층 사이의 j번째 다항식과의 곱을 통하여 로컬출력을 얻게 된다. 이와 같은 일련의 과정은 퍼지 추론과 동일한 절차를 가지며, 식 (16)와 같이 퍼지 추론식과 동일한 식으로 표현된다.

$$\hat{y} = \frac{\sum_{j=1}^c R_j(\mathbf{x}) \cdot f_j}{\sum_{j=1}^c R_j(\mathbf{x})} = \sum_{j=1}^c A_j(\mathbf{x}) \cdot f_j(\mathbf{x}) \quad A_j(\mathbf{x}) = \frac{R_j(\mathbf{x})}{\sum_{j=1}^c R_j(\mathbf{x})} \quad (16)$$

여기서, $A_j(\mathbf{x})$ 는 j번째 노드의 정규화된 적합도이며, $f_j(\mathbf{x})$ 는 j번째 노드의 다항식이 된다.

3. 클러스터링 기반 방사형 기저 함수 신경 회로망의 최적화

3.1 입자군집 최적화 알고리즘을 이용한 pRBF 뉴럴 네트워크의 최적화 방법

입자 군집 최적화 알고리즘을 이용한 클러스터링 기반 방사형 기저 함수 기반 다항식 신경 회로망의 설계 절차에 대해서 나타낸다[12]. 일반적인 모델의 구조 및 파라미터 선택은 설계자의 경험에 의해서 결정된다. 본 논문에서는 입자 군집 최적화를 이용하여 모델을 동조한다. 클러스터링 방법과 입자 군집 최적화 알고리즘을 이용한 다항식 방사형 기저 함수 신경 회로망의 최적화 설계 방법은 다음과 같다.

[단계 1] 데이터분할

N개의 입출력 데이터 $(\mathbf{x}_i, y_i) = (x_{1i}, x_{2i}, \dots, x_{ni}, y_i), i=1, 2, \dots, N$ 을 효율적인 모델링을 위해서 다음과 같이 데이터를 분할한다. 전체 데이터(N)를 학습 데이터(N_L)와 테스트 데이터(N_T)로 분할한다. 학습 데이터는 모델의 구조 및 파라미터를 결정하는데 사용하는 데이터이고, 테스트 데이터는 구축된 모델을 평가하기 위해 사용하는 데이터이다. 여기서, $N=N_L+N_T$ 이다.

[단계 2] PSO 알고리즘을 이용한 제안된 모델의 구조 및 파라미터 결정

PSO 알고리즘을 이용하여 제안된 모델의 구조 및 파라미터를 최적화한다. 적용된 클러스터링 방법에 따라 최적화 알고리즘으로 찾고자하는 파라미터가 다르다.

(a) K-Means 클러스터링 알고리즘의 경우

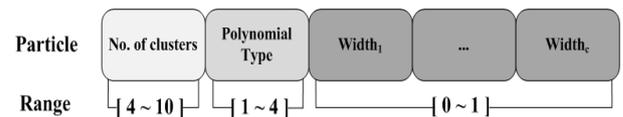


그림 3 K-Means 클러스터링 알고리즘일 때의 개체의 구조
 Fig. 3 Architecture of particle in case of K-Means clustering algorithm

(b) Fuzzy C-Means 클러스터링 알고리즘의 경우

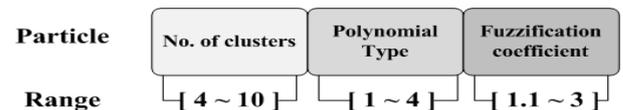


그림 4 Fuzzy C-Means 클러스터링 알고리즘일 때의 개체의 구조
 Fig. 4 Architecture of particle in case of Fuzzy C-Means clustering algorithm

그림 3의 경우 활성화 영역 대신 퍼지화 계수를 최적화한다. FCM 알고리즘에서 퍼지화 계수의 역할은 식(12)을 이용한 소속값을 구할 때 소속행렬의 분포영역을 조절한다.

다시 말해 활성함수의 활성화 영역과 같은 역할을 한다.

[단계 3] 적합도 생성 및 비교

[단계 2]의 파라미터를 이용하여 모델을 구축한 후 성능지수를 구한다. 이때 성능지수는 식 (17)과 같이 MSE (Mean Squared Error)를 사용하여 구한다.

$$E = \frac{1}{N} \sum_{i=1}^N (y_i - \hat{y}_i)^2 \quad (17)$$

[단계 4] 종료조건 판정

초기 주어진 반복횟수를 만족하였으며, 알고리즘을 종료하며, 그 때의 최적의 정보를 갖는 개체를 가지고 최종 모델을 구축한다. 종료조건을 만족하지 않으면, [단계 2]로 되돌아간다.

그림 5은 PSO를 이용한 제안된 모델의 최적화 과정을 나타낸다. 제안된 모델에 적용된 클러스터링 알고리즘에 따라 그림 3와 4같이 입자 군집 최적화 알고리즘의 개체 구성만 달라지며, 최적화 과정은 동일하다.

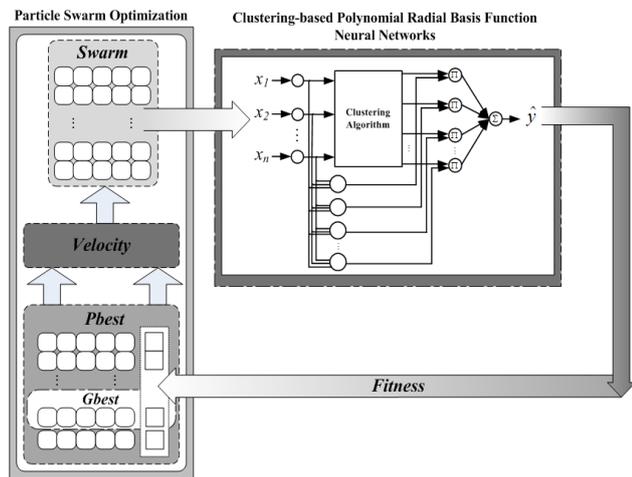


그림 5 입자 군집 최적화를 이용한 제안된 모델의 최적화 과정
 Fig. 5 Optimization process of proposed models using PSO

4. NXT 장비 센서를 이용한 실험데이터 취득 방법

본 연구에서 실험 데이터를 취득하기 위해 LEGO사에서 교육용으로 제작한 NXT 장비를 사용하였으며, 기본적으로 세 개의 센서(Sound sensor, Light sensor, Ultrasonic sensor)를 가지고 있다. 실험 데이터의 취득은 LabVIEW를 이용하였으며 NI(National Instrument)에서 제공하는 NXT Tool을 사용하였다.

4.1 NXT 장비 센서

NXT 장비에서 사용한 센서는 모두 세 개이며 Sound센서는 데시벨 즉, 소리의 크기 및 강도를 감지하는 센서로 사용되며 최종적으로는 거리를 측정하게 된다. Ultrasonic센서는 음파가 어떠한 물체에 부딪혀서 되돌아오는 시간을 환산하여 거리를 측정하는 센서이다. Light센서는 밝고 어두움의

구분과 실내에서의 광도 감지 및 채색된 표면의 광도를 감지하는 센서이다.



(a) Sound sensor (b) Light sensor (c) Ultrasonic sensor

그림 6 실험에 사용된 센서 종류

Fig. 6 Types of sensor used for experiment

4.2 NXT 센서 데이터 취득

NXT 장비 센서 데이터 취득은 LabVIEW 프로그램 기반으로 NI(National Instrument)에서 제공하는 NXT toolkit을 사용하여 데이터를 취득 한다. 취득하는 샘플링 데이터는 1ms로 각 거리(10~60cm)에서 5cm간격으로 100개의 데이터를 취득한다. 취득 방법으로는 물체를 위치시키고 그 앞에 일정한 소리가 나는 NXT장비를 위치한다. 센서가 장착된 NXT 장비를 실험자가 5cm간격으로 이동하여 각 위치에서 센서데이터 값이 정확히 취득 되는지 확인한다.

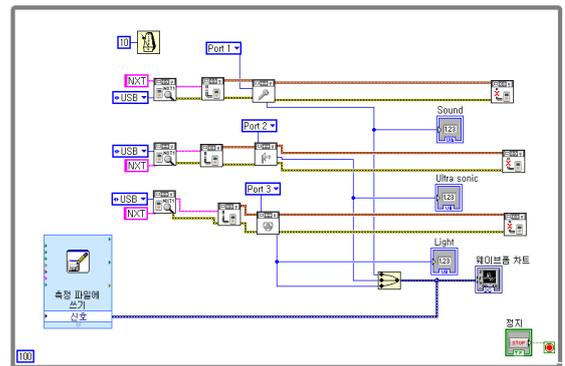


그림 7 LabVIEW 블록다이어그램

Fig. 7 LabVIEW block diagram

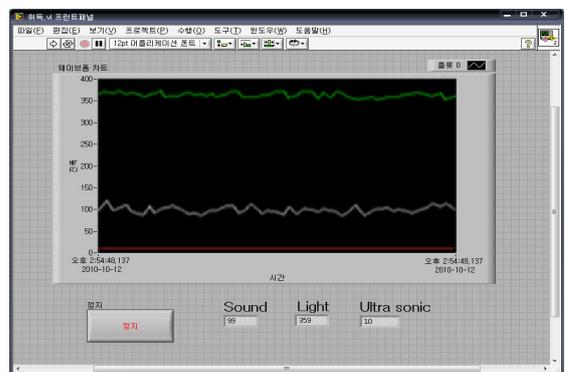


그림 8 LabVIEW 프런트 패널

Fig. 8 LabVIEW front panel

5. 시뮬레이션 및 결과 고찰

전체 데이터의 수는 총 1099개를 수집하였으며, 이를 학습 데이터와 평가데이터를 6:4로 분할하여 학습 데이터 수는 659개, 평가 데이터는 440개로 사용하였다. sound 센서, light 센서, 그리고 ultrasonic 센서로 수집한 데이터를 가지고 모델의 최종출력으로 사물의 거리를 예측하는 상황 인지 시스템을 설계하였다. 제안된 모델의 성능은 데이터를 바탕으로 모델링을 수행한 후 모델의 출력과 실제 거리를 평균 제곱 오차(Mean Square Error; MSE)를 사용하여 성능지수를 나타내었다. 아래의 case는 주어진 세 개의 센서를 각각 조합하여 실험을 수행하였다. case 별로 나누어 실험하는 목적은 세 개의 센서 중 하나가 사용이 불가능할 때 나머지 두 개의 센서를 가지고 상황 인지 시스템으로써의 역할을 수행할 수 있는지를 판단하고자 한다. 또한 입력데이터에 5dB 및 10dB white gaussian noise를 삽입하여 외란이 주어질 때의 모델 성능을 평가한다. case별 사용되는 센서는 다음과 같다.

- Case 1 : Sound sensor and Light sensor
- Case 2 : Sound sensor and Ultrasonic sensor
- Case 3 : Ultrasonic sensor and Light sensor
- Case 4 : Sound sensor, Light sensor, and Ultrasonic sensor

표 2는 입자 군집 최적화 알고리즘의 파라미터 설정 값을 나타낸다. 세대 수는 100세대로 설정하였으며, 인구 수(군집 수)도 100개의 개체를 이용하였다. 또한 하중계수(Inertial wight; w)는 0.9에서 0.4로 선형적으로 감소시켜 이동속도를 조절하였다.

표 2 PSO 알고리즘 및 모델 구축을 위한 정보

Table 2 Values of the parameters of the PSO algorithm and the proposed model

	Parameters	Values
PSO	Generation	100
	Swarm	100
	V_{max}	20%
	$[W_{min} W_{max}]$	[0.4 0.9]
	C_1, C_2	2.0

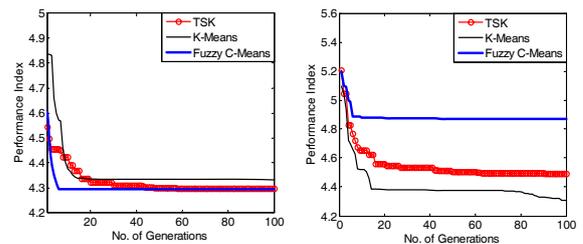
표 3는 sound sensor와 light sensor의 데이터를 실험한 결과를 나타낸다. without noise의 경우 직접 실험을 통해 추출한 데이터이며, with 5dB and 10dB noise의 경우 앞서 입력 데이터에 노이즈를 삽입한 데이터이다. 표3는 case 1의 실험결과로 노이즈가 포함된 데이터와 포함되지 않은 데이터의 성능지수가 비슷함을 알 수 있다.

그림 9는 데이터별 학습데이터의 최적화 과정을 보여준다. 노이즈가 없을 때는 FCM으로 은닉층을 구성할 때 모델의 성능이 가장 우수하지만 노이즈가 포함된 경우 KM으로 구성된 모델의 학습데이터의 성능(PI) 및 테스트데이터의 성능(EPI)이 더 우수함을 알 수 있다.

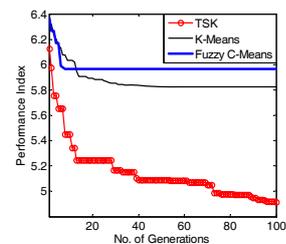
표 3 Case 1 일 때의 제안된 모델의 성능평가

Table 3 Performance of the proposed model in case of Case 1

Model	No. of Inputs	No. of Clusters	Polynomial type	Fuzzification coefficient	PI	EPI	
<i>Without noise</i>							
TSK Fuzzy model	2	9	Quadratic	-	4.2970	139.701	
Proposed model	KM	2	10	Quadratic	-	4.3333	4.6417
	FCM	2	10	Quadratic	1.4753	4.2961	4.9321
<i>With 5dB noise</i>							
TSK Fuzzy model	2	9	Quadratic	-	4.4934	22.017	
Proposed model	KM	2	10	Quadratic	-	4.3069	4.9231
	FCM	2	10	Quadratic	2.2051	4.8710	5.1656
<i>With 10dB noise</i>							
TSK Fuzzy model	2	9	Quadratic	-	4.9153	85.165	
Proposed model	KM	2	10	Quadratic	-	5.8220	6.5918
	FCM	2	10	Quadratic	2.3319	5.9665	7.0309



(a) without noise (b) 5dB noise



(c) 10dB noise

그림 9 데이터 별 최적화 과정 (Case 1)

Fig. 9 Optimization process according to dataset (Case 1)

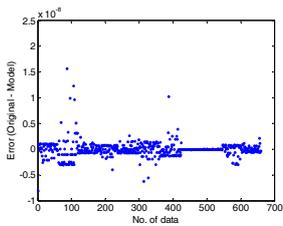
표 4는 sound sensor와 ultrasonic sensor 수집한 데이터를 바탕으로 실험한 결과를 나타낸다. without noise의 경우 세 모델 모두 학습 데이터와 테스트 데이터의 성능지수가 우수함을 알 수 있다.

그림 10은 실제 출력과 KM 클러스터링 기반 다항식 방사형 기저함수 신경회로망의 출력의 오차를 나타낸 그래프다. 그림 10(a)는 노이즈가 포함되지 않은 데이터로 거리가 멀어져도 각 오차의 분포가 일정함을 알 수 있다. 하지만 노이즈가 포함된 그림 10(b)와 (c)의 경우 거리가 멀어질수록 오차가 커짐을 알 수 있다.

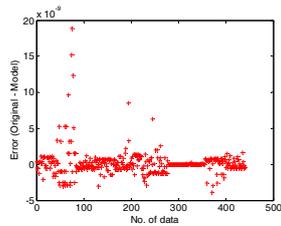
표 4 Case 2 일 때의 제안된 모델의 성능평가

Table 4 Performance of the proposed model in case of Case 2

Model	No. of Inputs	No. of Clusters	Polynomial type	Fuzzification coefficient	PI	EPI	
<i>Without noise</i>							
TSK Fuzzy model	2	6	Quadratic	-	2.7146e-22	1.4767e-08	
Proposed model	KM	2	6	Quadratic	-	3.3819e-18	2.4196e-18
	FCM	2	9	Quadratic	1.1353	3.7736e-15	6.3650e-09
<i>With 5dB noise</i>							
TSK Fuzzy model	2	9	Quadratic	-	1.3656	2.2304	
Proposed model	KM	2	10	Quadratic	-	1.1704	1.7584
	FCM	2	10	Quadratic	1.7183	1.2639	1.7990
<i>With 10dB noise</i>							
TSK Fuzzy model	2	9	Quadratic	-	2.2379	156.301	
Proposed model	KM	2	10	Quadratic	-	2.3887	2.7011
	FCM	2	10	Quadratic	1.1171	2.5209	3.1059

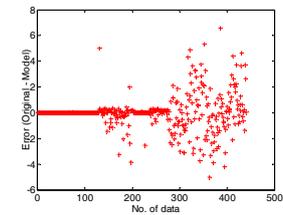


(a-1) Training

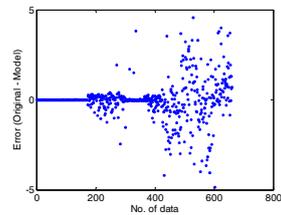


(a-2) Testing

(a) Without noise

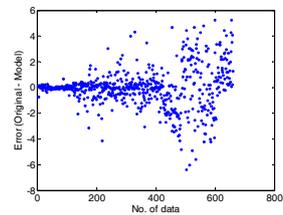


(b-1) Training

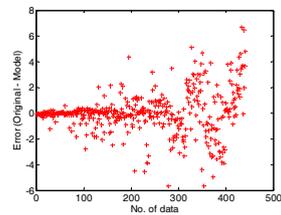


(b-2) Testing

(b) With 5dB noise



(c-1) Training



(c-2) Testing

(c) With 10dB noise

그림 10 KM 클러스터링일 때의 실제 출력과 모델출력의 오차 (Case 2)

Fig. 10 Error of original output and model output in case of K-Means clustering-based model (Case 2)

표 5은 ultrasonic sensor와 light sensor 수집한 데이터를 바탕으로 실험한 결과를 나타낸다. 앞선 case 2(sound and ultrasonic sensor)와 마찬가지로 노이즈 포함 여부에 따라 성능차이가 뚜렷하게 나타난다.

표 5 Case 3 일 때의 제안된 모델의 성능평가

Table 5 Performance of the proposed model in case of Case 3

Model	No. of Inputs	No. of Clusters	Polynomial type	Fuzzification coefficient	PI	EPI	
<i>Without noise</i>							
TSK Fuzzy model	2	9	Quadratic	-	8.0410e-25	9.5995e-25	
Proposed model	KM	2	8	Quadratic	-	7.5374e-25	1.9779e-24
	FCM	2	10	Quadratic	1.7442	8.1683e-26	1.1466e-25
<i>With 5dB noise</i>							
TSK Fuzzy model	2	9	Quadratic	-	3.2591	5.5250	
Proposed model	KM	2	10	Quadratic	-	2.5785	6.1102
	FCM	2	10	Quadratic	1.6268	2.8449	4.4776
<i>With 10dB noise</i>							
TSK Fuzzy model	2	9	Quadratic	-	8.9045	69.3146	
Proposed model	KM	2	10	Quadratic	-	8.9343	71.4439
	FCM	2	9	Quadratic	1.1580	8.9592	11.072

표 6은 3개의 센서 데이터를 바탕으로 실험한 결과를 나타낸다. 제안된 클러스터링 기반 방사형 기저 함수 신경회로망 모델은 4개의 case 중에서 가장 우수함을 알 수 있다. 하지만 TSK 퍼지 모델의 경우 노이즈가 삽입된 데이터의 경우 테스트 데이터의 성능지수가 발산 하는 것을 알 수 있다.

표 6 Case 4 일 때의 제안된 모델의 성능평가

Table 6 Performance of the proposed model in case of Case 4

Model	No. of Inputs	No. of Clusters	Polynomial type	Fuzzification coefficient	PI	EPI	
<i>Without noise</i>							
TSK Fuzzy model	3	12	Quadratic	-	1.1078e-22	1.5867e-22	
Proposed model	KM	3	8	Quadratic	-	9.0809e-16	7.7470e-10
	FCM	3	10	Quadratic	1.1000	4.7595e-15	1.3874e-8
<i>With 5dB noise</i>							
TSK Fuzzy model	3	27	Quadratic	-	0.5775	1558.0	
Proposed model	KM	3	10	Quadratic	-	0.9533	1.8723
	FCM	3	10	Quadratic	1.7544	1.2195	1.8952
<i>With 10dB noise</i>							
TSK Fuzzy model	3	27	Quadratic	-	0.9475	2362.0	
Proposed model	KM	3	9	Quadratic	-	2.3819	3.9861
	FCM	3	10	Quadratic	1.4890	2.5170	3.7387

5. 결 론

본 논문에서는 클러스터링 기반 다항식 방사형 기저 함수 신경회로망의 설계를 통한 상황 인지 시스템을 구현하였다. 모델의 구조 및 파라미터를 최적화하기 위해 입자 군집 최적화 알고리즘을 적용하였다. 최적화 알고리즘을 이용하여 모델의 클러스터링 수, 퍼지화 계수, 다항식 차수 등 모델의 필요한 파라미터들을 동조하였다. 상황 인지 시스템의 실험 데이터 만들기 위해 NXT 장비를 이용하였으며 세 개의 센서를 가지고 실제 사물과 센서간의 거리 데이터를 직접 추출하였다. 또한 세 개의 센서 중 하나를 사용할 수 없을 때를 가정하여 case별로 나누어 실험하였으며, 추가적으로 데이터에 노이즈를 삽입하여 모델의 외란특성을 확인하였다. 학습 데이터의 성능은 KM 기반 모델과 FCM 기반 모델에서 비슷하게 나타나지만 테스트 데이터 측면에서는 FCM 알고리즘을 사용하였을 때 출력이 발산하지 않고 좀 더 안정적인 성능지수를 나타냈다. 이 제한된 지능구조를 통해 제한된 영역 내에서 효과적인 상황인지 시스템 구현으로 그 응용면에서 적용 가능성을 확인하였다.

감사의 글

이 논문은 2009년도 정부(교육과학기술부)의 재원으로 한국연구재단의 지원을 받아 수행된 연구임(NRF-2009-0074928), 경기도의 경기도지역 협력연구센터사업의 일환으로 수행하였음[GRRRC 수원 2011-B2, U-city 보안감시 기술협력센터], 그리고 교육과학기술부로부터 지원받아 수행된 연구임(지역거점연구단육성사업/헬스케어기술개발사업단)

참 고 문 헌

[1] A. A. Frolov, D. Husek, I. P. Muraviev, P. Y. Polyakov, "A Boolean Factor Analysis by Attractor Neural Network," IEEE Trans. Neural Networks, Vol. 3, pp. 698-707, 2007.

[2] R. A. Aliev, B. G. Guirimov, B. Fazlollahi, and R. R. Aliev "Evolutionary Algorithm-based Learning of Fuzzy Neural Networks. part 2: Recurrent Fuzzy Neural Networks," Fuzzy Sets and Systems, Vol. 160, No. 17, pp. 2553-2566, 2009.

[3] S. B. Roh, S. K. Oh, and W. Pedrycz, "A Fuzzy Ensemble of Parallel Polynomial Neural Networks with Information Granules formed by Fuzzy Clustering," Knowledge-Based Systems, Vol. 23, No. 3, pp. 202-219, 2010.

[4] S. K. Oh, W. D. Kim, W. Pedrycz, and B. J. Park, "Polynomial-based Radial Basis Function Neural Networks (P-RBF NNs) Realized with the Aid of Particle Swarm Optimization," Fuzzy Sets and Systems, Vol. 163, No. 1, pp. 54-77, 2011.

[5] S. K. Oh, W. Pedrycz, and S. B. Roh, "Genetically Optimized Hybrid Fuzzy Set-based Polynomial Neural Networks," Journal of the Franklin Institute, Vol. 348, No. 2, pp. 415-425, 2011.

[6] S. B. Roh, S. C. Joo, W. Pedrycz, and S. K. Oh, "The development of fuzzy radial basis function neural networks based on the concept of information ambiguity," Neurocomputing, Vol. 73, No.13-15, pp. 2464-2477. 2010.

[7] James C. Bezdek, Robert Ehrlich, William Full "FCM: The Fuzzy C-Means Clustering Algorithm" Computers & Geosciences, Vol. 10, No. 2-3, pp. 191-203, 1984.

[8] S. P. Lloyd, "Least Squares Quantization in PCM," IEEE Trans. on Inf. Theory, Vol. 28, No. 2, pp. 129-137, 1982.

[9] J. Wang, J. Liu, and L. Liu, "A Mountain Means Clustering Algorithm," Intelligent Control and Automation, (WCICA 2008. 7th World Congress on), pp. 5045-5049, 2008.

[10] N. R. Pal, and D. Chakraborty, "Mountain and Subtractive Clustering Method: Improvements and Generalizations," International Journal of Intelligent Systems, Vol. 15, No. 4, pp. 329-341, 2000.

[11] J. Holland, "Adaptation In Natural and Artificial Systems," University of Michigan Press, 1975.

[12] J. Kennedy and R. Eberhart, "Particle Swarm Optimization," Proc. of IEEE International Conference on Neural Networks, Vol. 4, pp. 1942-1948, 1995.

[13] M. Dorigo and L.M. Gambardella, "Ant Colony System : A Cooperative Learning Approach to the Traveling Salesman Problem," IEEE Transactions on Evolutionary Computation, Vol. 1, No. 1, pp. 53-66, 1997.

[14] D. Karaboga, B. Akay, "A Survey: Algorithms Simulating Bee Swarm Intelligence," Artificial Intelligence Review, Vol. 31, No. 1, pp. 68-85, 2009.

저 자 소 개



오 성 권 (吳 聖 權)

1981년 : 연세대학교 전기공학과 졸업.
 1983년 : 동 대학원 전기공학과 졸업(석사). 1983~1989년 : 금성산전연구소(선임 연구원). 1993년 : 연세대 대학원 전기공학과 졸업(공학). 1996~1997년 : 캐나다 Manitoba대학 전기 및 컴퓨터공학과 Post-Doc. 1993~2005년 : 원광대 전기전자 및 정보공학부 교수 2005년~현재 : 수원대 전기공학과 교수. 2002년~현재 : 대한전기학회, 지능시스템학회 및 제어로봇시스템공학회 편집위원.
 Tel : (031) 229-8162
 Fax : (031) 220-2667
 E-mail : ohsk@suwon.ac.kr



나 현 석 (羅 炫 奭)

2010년 수원대학교 전기공학과 졸업.
2010년~현재 동 대학원 석사 과정
관심분야는 뉴럴 네트워크, Granular Computing, 진화론적 최적화 알고리즘 Computational Intelligence 등.
Tel : (031) 222-6544
Fax : (031) 220-2667
E-mail : hsn@suwon.ac.kr



김 욱 동 (金 旭 東)

2009년 수원대학교 전기공학과 졸업.
2011년 동 대학원 석사. 2011년~현재 동 대학원 박사과정. 관심분야는 퍼지추론 시스템, 뉴럴 네트워크, Granular Computing, 진화론적 최적화 알고리즘 Computational Intelligence 등.
Tel : (031) 222-6544
Fax : (031) 220-2667
E-mail : wdkim@suwon.ac.kr